

## ANALIZA RASPODJELE POVRŠINA ZAHVAĆENIH ŠUMSKIM POŽAROM NA OTOCIMA BRAČU, KORČULI I RABU

### ANALYSIS OF DISTRIBUTION OF AREAS AFFECTED BY FOREST FIRES ON ISLAND OF BRAČ, ISLAND OF KORČULA AND ISLAND OF RAB

Roman ROSAVEC\*, Damir DOMINKO\*\*, Damir BARČIĆ\*, Damir STAREŠINIĆ\*\*,  
Željko ŠPANJOL\*, Katica BILJAKOVIĆ\*\*, Marko OŽURA\*\*\*,  
Nera MARKOVIĆ\*, Dario BOGNOLO\*\*\*\*

*SAŽETAK:* Šume prekrivaju približno četvrtinu zemljine površine, i kao jedan od najvećih izvora kisika u prirodi važne su za opstanak života na Zemlji. Šumski požari kao vrlo važan fenomen za sam opstanak šuma, uz šumarstvo i ekologiju počeli su se proučavati i u fizici. U fizici je šumski požar prepoznat kao primjer kompleksnog sustava na velikim, kilometarskim skalama. Računalne simulacije omogućile su nova saznanja o šumskim požarima. U radu su korišteni podaci o broju požara i opožarenoj površini, prikupljeni u šumarijama Brač, Korčula i Rab, u razdoblju od 1991. godine do 2000. godine, koji su obrađeni primjenom fizikalnih modela, pomoću kojih se može saznati kako se požari šire, koji sve parametri i u kojoj mjeri utječu na širenje požara, te najvažnije – kako predvidjeti požare određenih razmjera. Rezultati istraživanja pokazuju da kumulativna raspodjela spaljenih površina na izabranim otocima slijedi zakon potencije u skladu s modelom Malamuda i drugih (1998). Logaritamski prikaz rezultata je pravac u najvećem dijelu. Nagib odgovara eksponentu  $\alpha$ , jer je  $-dN_{CF}/dA_F \approx AF^{-\alpha}$ . Prema navedenom modelu, ako su poznati zadani parametri nekog sustava možemo odrediti frekvenciju širenja požara, koja nam govori kolika je vjerojatnost pojave požara na nekoj površini. Skup podataka za naša tri otoka pokazuje da je s obzirom na dobiven nagib pravca za ukupan broj požara  $a = 1.02 \pm 0.02$  frekvencija širenja velika, što govori da je vjerojatnost širenja požara manja. Međutim, detaljnijom analizom dvije grupe podataka za veće požare dobije se veći nagib, što govori da je u idućih nekoliko godina rizik od požara velik, i to točno na područjima na kojima su izgorjele velike površine (na Korčuli čak do 55 km<sup>2</sup>). Iz dobivenih rezultata moguće je zaključiti da se vrijednosti nagiba pravca podudaraju za male i srednje požare, odnosno za veće frekvencije širenja kod primijenjenog modela, dok za veće požare postoje odstupanja kod primjene modela zbog konačnih dimenzija prostora. Dobiveni

\* Izv. prof. dr. sc. Željko Španjol, doc. dr. sc. Damir Barčić, Roman Rosavec, dipl. ing. šum., Nera Marković, dipl. ing. šum., Zavod za ekologiju i uzgajanje šuma, Šumarski fakultet Sveučilišta u Zagrebu, Svetošimunska 25, 10 000 Zagreb, e-mail: spanjol@sumfak.hr

\*\* Dr. sc. Katica Biljaković, dr. sc. Damir Starešinić, Damir Dominko, dipl. ing., Institut za fiziku, Bijenička 46, 10 000 Zagreb, e-mail: katica@ifs.hr

\*\*\* Marko Ožura, dipl. ing. šum., Veleučilište u Karlovcu, Ivana Meštrovića 10, 47 000 Karovac, e-mail: marko.ozura@vuka.hr

\*\*\*\* Dario Bognolo, dipl. ing. stroj., Veleučilište u Rijeci, Trpimirova 2/V, 1 000 Rijeka, e-mail: dariobognolo@yahoo.it

rezultati su poticaj za daljnja istraživanja, jer je pokazano da se poznavanjem utjecaja različitih parametara povezanih sa širenjem požara na nekom prostoru mogu odrediti područja povećanog rizika od požara. Posebice ako je poznata raspodjela malih i srednjih požara.

*Ključne riječi: jadranski otoci, spaljena površina, računalne simulacije, kompleksni sustavi, požar.*

## UVOD – Introduction

Šume kao jedan od najvećih obnovljivih izvora u prirodi, iznimno su važne za čovjekov opstanak. Prekrivaju približno četvrtinu zemljine površine i predstavljaju pluća postojbine svih živih bića. Brzi tehnološki razvoj znatno je unaprijedio život čovjeka, ali i dao velik doprinos uništenju prirodne ravnoteže, te smanjenju biološke raznolikosti. Šumski požari postaju sve značajniji čimbenik u narušavanju prirodne ravnoteže, posebno zbog sve većeg utjecaja ljudi na njihov nastanak, kao i kontrolu i njihovo suzbijanje. U tom smislu ekologija požara predmet je istraživanja biofizike i ekologije (Johnson i Miyanihi 2001). Poglavitito procesi paljenja gorive tvari i prijenosa topline. Na taj način fizikalni procesi utječu na ekološke procese (Traubaud 1989, Johnson 1992, Whelan 1995, Bond i van Wilgen 1996).

Uzroci nastanka požara mogu biti različiti od prirodnih (visoke temperature u ljetnim mjesecima, udar грома) do onih uzrokovanih ljudskim nemarom (paljenje korova na poljoprivrednim površinama, bačen neugašen opušak, neugašena izletnička vatra, razni ekološki incidenti). Prema dosadašnjim ekološko-fitocenološkim spoznajama i iskustvu prema stupnju zapaljivosti, mogućnostima potpaljivanja vatre i brzini širenja požara možemo razlikovati nekoliko skupina šumske vegetacije (Bertović i Lovrić 1987). Postoji nekoliko klasifikacija šumskih požara. Kod nas se ona najčešće odnosi na način postanka požara, gdje razlikujemo prirodne i umjetne požare (Španjol, 1996). Najveće opasnosti od šumskih požara nastaju u ljetnim mjesecima (Vajda 1974). Stoga Flannigan i Wotton (2001) vremenske uvjete i klimu smatraju kritičnim čimbenicima u istraživanju požara.

## MATERIJAL I METODE – Material and methods

Za analizu su korišteni podaci prikupljeni u šumarijama Brač, Korčula i Rab o broju požara i površinama zahvaćenim požarima za desetogodišnje razdoblje, od 1991. godine do 2000. godine. Otoci se razlikuju prema zemljopisnom položaju, prema vegetaciji i mikroklimi, ali i prema protupožarnoj tradiciji. Korčula i Brač nalaze se u južnoj Dalmaciji i njihova vegetacija pripada dijelom mediteransko-litoralnom i dijelom mediteransko-montanskom vegetacijskom pojasu (Trinajstić, 1985, 1986). Rab je dio Kvarnera (Hrvatsko primorje) i vegetacijski pripada mediteransko-litoralnom vegeta-

cijskom pojasu. Prema istraživanjima Seletkovića i Katušina (1992) Brač i Korčula pripadaju *Csa* klimatskom području, dok je Rab definiran *Cfs a* tipom klime. Ukupan broj požara na sva tri otoka u razdoblju od 1991. godine do 2000. godine je 206. Najveći broj požara zabilježen je na Korčuli, ukupno 83 (izgorjele velike površine). Na Braču su zabilježena 72 požara. Najmanje 51 požar i to na najmanjim površinama zabilježen je na otoku Rabu.

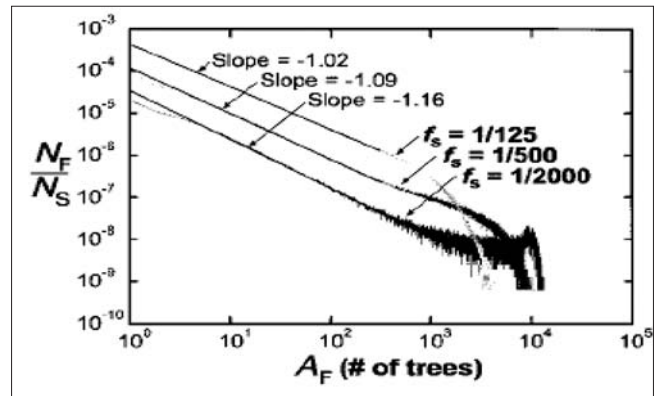
Jedan od najzanimljivijih primjera samoorganizirane kritičnosti je širenje šumskih požara. Proučavanjem modela koji ih vjerno opisuju možemo dobiti odgovore na pitanje kako se požari ponašaju, što sve utječe na njihovo širenje, kako slijede zakon potencije, i najvažnije kako ih predvidjeti. Ovaj rad je primjer moguće primjene fizikalnih modela na analizu raspodjele požarom zahvaćenih površina na tri otoka: Braču, Korčuli i Rabu.

Krenuli smo od modela u kojemu se požar širi u dvo-dimenzionalnoj (2D) rešetki kojega su razvili Mala-

mu d i dr. (1998). U rešetku se nasumično posadi drveće (u polje se može zasaditi samo jedno drvo) u nizu vremenskih serija točno zadanog broja. U određenom trenutku bacimo iskrnu i od tog polja počinje se širiti vatra. Frekvencija paljenja požara ( $f_s$ ) je obrnuto proporcionalna broju pokušaja da se posadi drvo u polje prije nego što požar zahvati nasumično odabrano polje. Ako je npr.  $f_s = 1/100$ , to znači da je bilo 99 pokušaja da se posadi drveće prije nego što se zapali neko polje u 100-tom vremenskom koraku. Ako iskra padne na prazno polje ništa se ne događa, ali ako padne na popunjeno polje, drvo izgori i požar dalje zahvaća iduća susjedna polja. To je načelo osnovnog modela. Za određenu frekvenciju paljenja požara točno je određen broj polja u rešetki ( $N_g$ ), broj vremenskih koraka ( $N_s$ ) te broj požara ( $N_F$ ). Računalnom simulacijom dobiva se izgorjela površina  $A_F$  ( $A_F$  je broj drveća uništen u svakom požaru).

$$N_F/N_S \sim A_F^{-\alpha} \tag{1}$$

Nekumulativni broj požara u određenom vremenskom koraku iznosi  $N_F/N_S$  i dan je kao funkcija od  $A_F$  na 2D rešetki dimenzija 128 x 128 za tri frekvencije:  $f_s = 1/125$ ,  $f_s = 1/500$ ,  $f_s = 1/2000$ . Slika 1. pokazuje tu nekumulativnu raspodjelu požara na log-log ljestvici. Nagib pravca predstavlja eksponent  $\alpha$  (vrijedi zakon potencija) koji ovisi o frekvenciji. Broj požara za svaki vremenski interval je funkcija broja drveća koje je izgorjelo u svakom od požara. Za svaku frekvenciju širenja požara postojalo je  $N_s = 1.638 \times 10^9$  vremenskih intervala. Također postoji raspon od malih do velikih požara, s mnogo više malih nego velikih. Mali i srednji požari dobro zadovoljavaju zakon potencija, uz  $\alpha = 1.02$  do  $1.09$ . Veliki požari pokazuju veća odstupanja ( $\alpha = -1.16$ ), što se vidi kod frekvencije 1/2000 zbog konačnih dimenzija rešetke. To je učinak ograničene veličine, jer nakon što se raširi po cijeloj rešetki, požar se zaustavlja.



Slika 1. Nekumulativna raspodjela broja požara, ovisno o broju izgorjelog drveća za tri frekvencije širenja požara prema Malamudu i dr. (1998). Najveći nagib je dobiven za najmanju frekvenciju.

Figure 1 Non-cumulative distribution of fire number in dependence on the number of burnt trees for three fire spread frequencies according to Malamud et al., 1998. The highest gradient was obtained for the smallest frequency.

Kod primjene modela na podatke za Brač, Korčulu i Rab, zbog relativno malog broja podataka, koristili smo kumulativnu raspodjelu da bi dobili kvalitativno dobre rezultate. Korištenje nekumulativne raspodjele dalo bi nepouzdana rješenja, s obzirom na malen broj požara imali bismo velika raspršenja. Raspodjelu kumulativnog broja površina  $N_{CF}$  za neki interval dobili smo tako da smo odabrali početni interval površina koji sadrži određen broj požara ( $A_1, \dots, A_{10}$ ), diskretnim pomacima, odnosno povećavanjem intervala, s povećanjem površina koje su bile zahvaćene požarom, povećava se i broj požara. Svaki novi požar uključuje i sve požare na manjim površinama. Za svaki interval izračunali smo metodom najmanjih kvadrata koeficijent nagiba pravca te srednju vrijednost ukupnog broja površina unutar zadanog intervala. Dobiveni parametri prikazani su u međusobnoj ovisnosti na log-log ljestvici.


## REZULTATI ISTRAŽIVANJA – Research results

Rezultati pokazuju da kumulativni broj požara u ovisnosti o spaljenim površinama slijedi zakon potencija (Slika 2.). Logaritamski prikaz rezultata je pravac u najvećem dijelu. Nagib odgovara eksponentu  $\alpha$ , jer je  $-dN_{CF}/dA_F \approx A_F^{-\alpha}$ .


Slika 2. Grafički prikaz derivacije kumulativne raspodjele broja svih požara jadranskih otoka Brača, Korčule, Raba u ovisnosti o zahvaćenoj površini u razdoblju od 1991. godine do 2000. godine. Dobiveni eksponent u području površina od jednog hektara do 100 km<sup>2</sup> je  $\alpha = -1.02 \pm 0.02$ .

Figure 2 Graphic presentation of the derivation of cumulative distribution of all fires on the Adriatic islands of Brač, Korčula and Rab in dependence on the affected area in the period from 1991 to 2000. The obtained exponent in the area ranges from one hectare to 100 km<sup>2</sup> is  $\alpha = -1.02 \pm 0.02$ .

Grafički prikaz rezultata može se podijeliti u tri područja. Prvi dio odnosi se na male površine (1-100 m<sup>2</sup>).



Male površine predstavljene su područjima velike frekvencije, odnosno male vjerojatnosti širenja požara. Takvi požari nisu opasni, jer nemaju tendenciju širenja i stvaranja požara na velikim površinama. Srednji požari su najbrojniji i zahvaćaju površine ( $100 \text{ m}^2 - 10 \text{ km}^2$ ). Frekvencija širenja požara je manja, a takvi požari imaju tendenciju širenja na velike površine. U velikim požarima uglavnom stradavaju šume četinjača velikih površina  $10 \text{ km}^2 - 55 \text{ km}^2$ . Iz grafičkog prikaza vidi se da je nagib pravca za male požare najbliži jedinici. Nagib pravca  $\alpha = -1.02 \pm 0.02$  pokazuje da je raspodjela kumulativnog broja požara za tri otoka (Brač, Korčulu i Rab) vrlo bliska prethodno opisnom modelu. Rezultati dobi-



Slika 3. Grafički prikaz derivacije kumulativne raspodjele broja malih i srednjih požara (do  $1 \text{ km}^2$ ) s eksponentom  $\alpha = -0.95 \pm 0.02$  (crna linija), te velikih požara ( $1 \text{ km}^2 - 55 \text{ km}^2$ ) s eksponentom  $\alpha = -1.45 \pm 0.09$  (crvena linija).

Figure 3 Graphic presentation of the derivation of cumulative small and medium fire distribution (up to  $1 \text{ km}^2$ ) with the exponent  $\alpha = -0.95 \pm 0.02$  (black line), and large-scale fires ( $1 \text{ km}^2 - 55 \text{ km}^2$ ) with the exponent  $\alpha = -1.45 \pm 0.09$  (red line).

## RASPRAVA – Discussion

Naše istraživanje pokazalo je da šumski požari na Braču, Korčuli i Rabu slijede zakon potencije i bliži su rezultatima računalnog modela nego rezultati istraživanja za požare diljem SAD-a i u Australiji danih na slici 4. Razlog za tu tvrdnju pronađen je u činjenici što naši podaci sadrže više manjih i srednjih površina nego velikih.

Za područje Aljaske samo u vremenu od 1990. godine do 1991. godine zabilježena su 164 požara. Vegetaciju na tom području čini gusta crnogorična šuma. Nagib pravca u log-log zapisu iznosi  $\alpha = -1.43$ . To je prilično veliko odstupanje od kompjutorskog modela, kao i u ostala tri slučaja sa slike 4., zbog toga što su uključene velike spaljene površine. Odstupanje je posljedica ograničenosti modela kod primjene na realne požare koji uvijek pokazuju prijelaz iz manjeg  $\alpha$ , za manje površine na veći  $\alpha$  za velike površine.

Naši rezultati bliži su rezultatima dobivenim za mediteransko klimatsko područje SAD-a, stoga se može govoriti o ovisnosti eksponenta o klimatskim podru-


veni za požare na tri dalmatinska otoka gotovo su istovjetni rezultatima dobivenim računalnim simulacijama.

Najveći doprinos daju male i srednje površine kojih ima najviše, pa čine dobar reprezentativni uzorak, a velikih površina ima nešto manje. Ukupan doprinos svih površina za dane požare (206) daje koeficijent koji ukazuje na veliku frekvenciju raspodjele. To znači da postoji manja vjerojatnost za širenje požara nego što bi vrijedilo da je koeficijent veći. Međutim, to može biti vrlo varljiv rezultat, jer imamo velik skup podataka za više otoka, a veličine spaljenih površina na otocima nisu slične već variraju. Tako Rab ima samo malene površine do maksimalno  $0.1 \text{ km}^2$ , dok Korčula ima puno velikih spaljenih površina. Otok Brač ima raspon od najmanjih do većih površina. Rezultati su podijeljeni u dva dijela, manji i srednji požari te veliki požari. Određeni su nagibi pravaca za ta dva područja (Slika 3).

Na temelju slike 3 vidljivo je da male površine (do  $1 \text{ km}^2$ ) imaju koeficijent nagiba  $\alpha = -0.95 \pm 0.02$ , dok za veće površine (do  $55 \text{ km}^2$ ) koeficijent pokazuje znatno veću vrijednost  $\alpha = -1.45 \pm 0.09$ . To je u skladu s očekivanjima, jer širenje velikih požara je ipak ograničeno graničnim veličinama, bilo u prirodi ili u računalnom modelu. Bitno je naglasiti da su dobiveni rezultati raspodjele broja požara dobiveni za sva tri otoka zajedno. Istovremeno ti otoci imaju mnogo zajedničkih svojstava koja su bitna za širenje požara: sličnu fraktalnu strukturu obale, sredozemnu klimu koju karakteriziraju duga, vruća i sušna ljeta koja pogoduju širenju požara, slične promjene u temperaturnom i vjetrovnom režimu, ali i rast vegetacije (nisko raslinje, makija, vazdazelene šume i šume četinjača).

čjima, što je pokazalo i novije istraživanje Malamuda i drugih (2005). Ustanovili su da je eksponent na području SAD najveći za subtropsku zonu, a najmanji upravo za mediteransku zonu (Slika 5). Mediteransko klimatsko područje ne obuhvaća isključivo zemlje Sredozemlja. Prema Fendell-u i Wolff-u (2001) navedeno područje podrazumijeva i južnu Kaliforniju, središnji Čile, zatim područje u Južnoj Africi oko Rta Dobre Nade i južni i jugozapadni dio Australije.

Prema Malamud-ovom modelu (1998) ako su poznati zadani parametri nekog sustava možemo odrediti frekvenciju širenja požara. Frekvencija širenja požara govori nam kolika je vjerojatnost pojave požara na nekoj površini. Iz raspodjele broja požara po površini možemo odrediti da li je frekvencija širenja mala ili velika. Skup podataka za naša tri otoka pokazuje da je s obzirom na dobiven nagib pravca za ukupan broj požara  $\alpha = 1.02 \pm 0.02$  frekvencija širenja velika, što govori da je vjerojatnost širenja požara manja. Međutim,

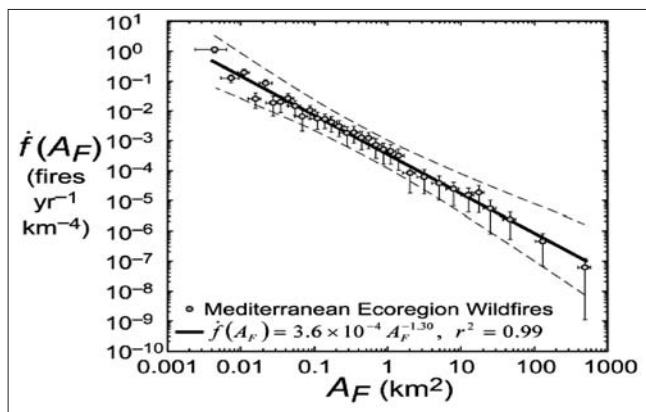


Slika 4. Kumulativna raspodjela broja požara ovisno o izgorenoj površini; A - 4000 požara u SAD u razdoblju od 1986. godine do 1995. godine, B - 120 najvećih požara na zapadu SAD do 1960. godine, C - 164 požara na Aljasci u razdoblju od 1990. godine do 1991. godine, D - 298 požara u Australiji u razdoblju od 1926. godine do 1991. godine (Malamud i dr. 1998).

Figure 4 Cumulative distribution of fire frequency in dependence on burnt areas; A - 4,000 fires in the USA over the time period from 1986 to 1995, B - 120 largest fires in the west of the USA up to 1960, C - 164 fires on Alaska in the period from 1990 to 1991, D - 298 fires in Australia over the time period 1926 - 1991 (Malamud et al. 1998).

detaljnijom analizom dvije grupe podataka za veće požare dobije se veći nagib, što govori da je u idućih ne-

koliko godina rizik od požara velik i to točno na područjima na kojima su izgorjele velike površine (na Korčuli čak do 55 km<sup>2</sup>). S obzirom da smo uzeli podatke za sva tri otoka zajedno, nije jasno vidljiv doprinos svakog pojedinog otoka. Otoci Korčula i Brač najveći doprinos daju malim i srednjim površinama za koje ovaj model daje najbolje rezultate. S druge strane na Rabu u tom razdoblju nije bilo požara koji je zahvatio više od 0.1 km<sup>2</sup> površine. Sigurno je na Rabu vjerojatnost pojave velikih požara niska. Dobiveno odstupanje u rezultatu je posljedica statističkog usrednjavanja ukupnog broja požara. Još jedan mogući razlog odstupanja leži u utjecaju vanjskih čimbenika: vremenski uvjeti, klima, vrsta vegetacije, ljudski naponi u gašenju požara i dr. Rezultati bi bili indikativniji kada bi bilo moguće obraditi svaki otok zasebno, međutim za sada ne postoji dovoljan broj podataka za svaki otok, iz kojih bi se mogla odrediti frekvencija širenja požara.



Slika 5. Kumulativna raspodjela broja požara u SAD od 1970. godine do 2000. godine u području s mediteranskom klimom ovisno o izgorenoj površini (Malamud i dr. 2005).

Figure 5 Cumulative distribution of fire frequency in the USA from 1970 to 2000 in Mediterranean-type climate regions in dependence on burnt areas (Malamud et al. 2005).

## ZAKLJUČAK – Conclusion

Analiza raspodjele spaljenih površina na tri jadranska otoka Rabu, Braču i Korčuli pokazala je da ona slijedi zakon potencije u skladu s modelom Malamuda i drugih (1998). Iz nagiba pravca u log-log zapisu može se izračunati frekvenciju širenja požara na nekom prostoru, odnosno vjerojatnost kako će se požar širiti na određenom području. Na temelju dobivenih rezultata moguće je zaključiti da se vrijednosti nagiba pravca podudaraju za male i srednje požare, tj. za veće frekvencije širenja kod primijenjenog modela. Za veće požare postoje odstupanja kod primjene modela zbog konačnih dimenzija prostora.

Primjena modela bila bi uspješnija kada bi postojao dovoljan broj poznatih parametara za svaki otok. Na taj način mogla bi se preciznije odrediti vjerojatnost širenja požara.

Dobiveni rezultati su poticaj za daljnja istraživanja. Poznavanjem utjecaja različitih parametara na širenje požara na nekom prostoru (posebice ako znamo kakva je raspodjela malih i srednjih požara) može se odrediti područja rizika od nastanka šumskog požara, što je vrlo bitno u prevenciji i organizaciji bolje protupožarne zaštite.

## LITERATURA – References

- Bertović, S., A. Ž. Lovrić, 1987: Vegetacija i kategorije njezine prirodne ugroženosti od požara, Osnove zaštite šuma od požara, 340 str., CIP, Zagreb.
- Bond, W. J., B. W. van Wilgen, 1996: Fire and Plants. Chapman and Hall, 259 p., London.
- Bunde, A., S. Mavlin, 1991: Fractals and Disordered Systems. Springer-Verlag.
- Fendell, F. E., M. F. Wolff, 2001: Wind-Aided Fire Spread, Forest Fires, Behavior and Ecological Effects, Academic Press, 171–223, San Diego.
- Flannigan, M. D., B. M. Wotton, 2001: Climate, Weather and Area Burned, Forest Fires, Behavior and Ecological Effects, Academic Press, 351–373, San Diego.
- Johnson, E. A., 1992: Fire and Vegetation Dynamics: Studies from the North American Boreal Forest, Cambridge University Press, Cambridge.
- Johnson, E. A., K. Miyanashi, 2001: Strengthening Fire Ecology's Roots, Forest Fires, Behavior and Ecological Effects, Academic Press, 1–9, San Diego.
- Malamud, B. D., G. Morein, D. L. Turcotte, 1998: Forest fires: An Example of Self-organized critical Behavior, Science, Vol. 281, Washington, D.C.
- Malamud, B. D., G. L. W. Millington Perry, 2005: Characterizing wildfire regimes in the United States, PNAS 102, 4694.
- Seletković, Z., Z. Katušin, 1992: Klima Hrvatske, Šume u Hrvatskoj, GHZ, 13–18, Zagreb.
- Španjol, Ž., 1996: Biološko-ekološke i vegetacijske posljedice požara u borovim sastojinama i njihova obnova, Disertacija, Šumarski fakultet Zagreb.
- Trabaud, L., 1989: Les Feux de Forêts: Mecanismes, Comportement et Environment, France-Selection, Aubervilliers Cedex, France.
- Trinajstić, I., 1985: Flora otočne skupine Korčule, Acta Botanica Croatica, Vol. 44: 107–130, Zagreb.
- Trinajstić, I., 1986: Fitogeografsko raščlanjenje šumske vegetacije istočnojadranskog sredozemnog područja – polazna osnovica u organizaciji gospodarenja mediteranskim šumama, Glas. šum. pokuse, posebno izdanje Vol. 2: 53–67, Zagreb.
- Vajda, Z., 1974: Nauka o zaštiti šuma, Školska knjiga, 482 str., Zagreb
- Whelan, R. J., 1995: The Ecology of Fire, Cambridge University Press, 346 p., Cambridge.

## ZAHVALA

Ovaj rad napravljen je u okviru znanstvenog Programa 0352827 **Korelacije u kompleksnim sustavima: od fizike do biotehnologije** Ministarstva znanosti, obrazovanja i športa, u kojega su uključeni projekti 068-0352827-0527 **Biotehničke mjere u zaštiti i obnovi**

**šuma od požara** i 035-0352827-2842 **Kompleksni modulirani sustavi: nova osnovna stanja, defekti i magnetski efekti**. Zahvaljujemo dipl. inž. Mariji Plodinec za njezin doprinos u ranoj izvedbi ovog istraživanja.

*SUMMARY: Forests cover approximately one fourth of the land's surface. As one of the largest oxygen sources in the nature, they are very important for the survival of life on Earth. Forest fires have become an increasingly interesting issue not only for forestry and ecology, which study them as an important*

phenomenon for the survival of forests themselves, but also for physics. Physics perceives forest fires as an example of a complex system on large, kilometer-long scales. Faithful computer simulations can answer different questions, such as how fires behave, what influences their propagation, how they follow the power law and most importantly, how fires of different sizes can be predicted.

In our work we used the data from the forest administrations of Brač, Korčula and Rab. The data, collected over the time period 1991 – 2000, relate to the number of fires and the size of the burned area. We began with a model in which a fire spreads in a two-dimensional (**2D**) grid developed by Malamud et al. (1998). There is an accurately defined number of boxes in the grid ( $N_g$ ), the number of time steps ( $N_t$ ) and the number of fires ( $N_f$ ) for a given fire ignition frequency. Computer simulation modeling provides a burned area  $A_F$  ( $A_F$  is the number of trees destroyed in each fire). A non-cumulative number of fires in a defined time period is  $N_f/N_t$  and is given as a function of  $A_F$  on a **2D** grid of  $128 \times 128$  for three frequencies:  $f_s = 1/125$ ,  $f_s = 1/5000$ ,  $f_s = 1/2000$ . The slope of direction represents the exponent  $\alpha$  (the power law applies) which depends on the frequency. The number of fires for every time interval is the function of the number of trees burned in each of the fires. For every fire propagation frequency there was the  $N_t = 1.638 \times 10^9$  of time intervals. There is also a range from small to large fires, with the number of small fires far exceeding that of large ones. Small and medium fires satisfy the power law, with  $\alpha = -1.02$  to  $1.09$ , while large fires exhibit bigger deviations ( $\alpha = -1.16$ ), as manifested at frequency  $1/2000$  due to the finite grid dimensions. This is the limited size effect, since the fire stops after it has spread across the entire grid.

In our application of the model to the data for Brač, Korčula and Rab, due to the relatively small number of data we used cumulative distribution in order to obtain qualitatively good results. By increasing the initial area interval that contains a given number of fires ( $A_1, \dots, \dots, A_{10}$ ), the fire affected area increases and so does the number of fires. This provided a distribution of the cumulative area number  $N_{CF}$  for an interval. The results of our research show that the cumulative distribution of burned areas in the selected islands follows the power law in accordance with the model by Malamud et al. (1998). A logarithmic presentation of the results is a direction in its major part. The slope corresponds to the exponent  $\alpha$ , because  $-dN_{CF}/dA_F \approx A_F^{-\alpha}$ . According to the above model, if we know the parameters of the system we can determine fire propagation frequency, which indicates the probability of fire occurrence in an area. A data set for the three Croatian islands shows that, in relation to the obtained slope of direction for the total number of fires  $\alpha = 1.02 \pm 0.02$ , the fire propagation frequency is high, meaning that the probability of fire propagation is lower. However, a more detailed analysis of the two data sets for larger fires results in a greater slope, indicating a high risk of fire in the next several years, particularly in the areas that have already been severely burned (e.g. as many as  $55 \text{ km}^2$  on the island of Korčula). The obtained results allow us to conclude that in the applied model, the direction slope values coincide for small and medium fires, i.e. for higher spread frequencies, while the model used for larger fires exhibits deviations due to the finite space dimensions. The results provide a stimulus for further research, because it has been shown that if the impact of different parameters related to fire spread in an area is known, it is possible to identify areas with an increased fire risk, particularly in case of small and medium fire distribution.

**Key words:** Adriatic islands, burned area, computer simulations, complex systems, fire.